

Siete typu counterpropagation (Counter propagation networks)

Siete typu **ART**

ART = Adaptive Resonance Theory

Siete typu counterpropagation (CPN)

▶ **Základná idea CPN**

- ▶ **Ciel'**: rýchla a hrubá aproximácia mapovania vektorov

$$y = \phi(x)$$


- ▶ Nemapovať žiadne dané x na $\phi(x)$ s vopred danou presnosťou,
- ▶ Vstupné vektory x budú rozdelené do klastrov/tried.
- ▶ Každý klaster/trieda má jeden výstup y , ktorý je (dúfame) priemerom $\phi(x)$ pre všetky x v tomto klasteri/triede.

Siete typu counterpropagation (CPN)

- ▶ Hecht – Nielsen, 1986
- ▶ CPN pracuje ako vyhľadávacia tabuľka, ktorá k danému vstupu nájde najbližšieho reprezentanta a odpovie výstupnou hodnotou, ktorá je s týmto reprezentantom spojená

CPN

- ▶ **Architektúra:**
- ▶ Jednoduchý prípad: **DOPREDNÁ CPN**



**Od vstupu ku
skrytej (triede)**

**Od skrytej (triedy)
k výstupu**

CPN

- ▶ CPN pozostáva z troch vrstiev
- ▶ Vstupnú vrstvu tvorí n vstupných neurónov, ktoré distribuujú do ďalšej vrstvy vstupné signály x_1, x_2, \dots, x_n
- ▶ Druhá vrstva je tvorená p samoorganizačnými jednotkami, ktorej váhy označíme w_j a výstupy y_j
- ▶ Tretiu vrstvu tvorí m Grossbergových jednotiek *instar* s výstupnými váhami v_r ($r=1, \dots, m$). Výstupy jednotiek y_r tvoria výstup celej siete.

Učenie CPN v dvoch fázach:

- ▶ Trénovacia vzorka (\mathbf{x}, \mathbf{d}) kde $\mathbf{d} = \phi(\mathbf{x})$ je predpokladané presné mapovanie.
- ▶ **Fáza 1:** Váhy w_k vstupujúce do skrytého neurónu z_k sú trénované použitím **súťažného učenia** (*competitive learning*), aby sa stali reprezentatívnymi vektormi pre klaster/triedu vstupných vektorov x : (použiť len x zo vstupu (x, d))

1. Pre vybrané \mathbf{x} , dopredným šírením určiť víťaza z_{k^*}
2. $w_{k^*,i}(\text{new}) = w_{k^*,i}(\text{old}) + \eta (x_i - w_{k^*,i}(\text{old}))$
3. Upraviť η , opakovať kroky 1 a 2 do splnenia podmienky zastavenia

η je učiaci pomer

Učenie CPN v dvoch fázach:

- ▶ **Fáza 2:** Váhy v_k idúce od skrytých neurónov z_k na výstup sú trénované pomocou **pravidla delta** (*delta rule*), aby sa stali priemerným výstupom $\phi(x)$ kde x je vstupný vektor, ktorý
 - ▶ určí z_{k^*} za víťaza (treba použiť aj x aj d).
1. Pre vybrané x , dopredným šírením určiť z_{k^*}
 2. $w_{k^*,i}(new) = w_{k^*,i}(old) + \eta(x_i - w_{k^*,i}(old))$ (η voliteľné)
 3. $v_{j,k^*}(new) = v_{j,k^*}(old) + \eta(d_j - v_{j,k^*}(old))$
 4. Opakovať kroky 1-3 pokiaľ nie je splnená podmienka zastavenia

CPN – štatistické vlastnosti

- ▶ Jednotky v druhej vrstve majú rovnakú pravdepodobnosť víťazstva za predpokladu, že vyberáme vstupy náhodne s rozložením zodpovedajúcim tréningovej množine.
- ▶ Váhy výstupných jednotiek sú adaptované tak, aby aproximovali priemernú výstupnú hodnotu patriacu tým vstupom, ktoré aktivovali zodpovedajúce jednotky v druhej vrstve.

Príklad

- ▶ $n = 3$ (vstup), $m = 2$ (výstup),
- ▶ $p = 4$ (počet neurónov v skrytej vrstve)

- ▶ Vstupy a očakávané triedy
- ▶ $((1, 2, 4), (1, 1))$
- ▶ $((-1, -2, 2), (-1, -1))$
- ▶ $((3, 3, 3), (1, -1))$

- ▶ $W1 = (2, 1, 2)$, $W2 = (3, 4, 2)$, $W3 = (-1, -2, 4)$, $W4 = (3, 2, 1)$
- ▶ $V1 = (1, 2, 1, 3)$, $V2 = (2, 4, -3, 1)$

ART Siete

- ▶ Úvod do **A**daptívnej **R**ezonančnej **T**eórie
- ▶ ART - motivácia a základné rysy
- ▶ ART – základná architektúra
- ▶ ART – základné operácie
- ▶ ART1 siete a ich učiaci algoritmus
- ▶ Analýza učiaceho algoritmu

Adaptívna rezonančná teória

- ▶ **Adaptive Resonance Theory (ART)** – spracoval Grossberg v roku 1970 s cieľom analyzovať spracovanie kognitívnych informácií
- ▶ Jeho návrh zahŕňa pamäťovú stabilitu s rýchlym alebo pomalým učením sa v otvorenom a vyvíjajúcom sa prostredí

Adaptívna rezonančná teória

- ▶ Carpenterová spolu s inými realizovala vyššie princípy ako kvantitatívne systémy a pridávala nové poznatky do originálnej teórie
- ▶ Dilema *stability/plasticity (S/P)* v neurónových sieťach.
- ▶ ART siete sú schopné riešiť túto dilemu.

Adaptívna rezonančná teória

- ▶ **Mozog je schopný samoorganizácie a rýchleho autonómneho učenia sa** vedúceho k stabilným vedomostiam v prostredí, ktoré je výrazne nestacionárne, a ktoré predstavuje ohromné množstvo dát.
- ▶ **?Ako je mozog schopný riešiť** tento kľúčový problém.
Toto je veľmi dôležité vedieť pre technologické aplikácie založené na rozpoznávaní známych vzoriek alebo pre predikčné aplikácie.

Adaptívna rezonančná teória

- ▶ „**Dilema stability a plasticity**“ (**Stability-plasticity dilemma**) - požiadavka, aby systém bol schopný nepretržitého stabilného učenia sa bez nebezpečenstva, že by zabúdal vedomosti kritické pre jeho ďalšiu existenciu

Adaptívna rezonančná teória

Plasticita:

- ▶ Systém v priebehu učenia sa generuje rozpoznávacie kódy ako odozvu na postupnosť vstupných vzoriek z okolitého prostredia.
- ▶ Pritom sa postupne **vytvárajú takzvané vzorky kritických príznakov**, čo znamená, že každý rozpoznávací kód si ponechá len tie príznaky, ktoré ho odlišujú od kódov ostatných tried.

Adaptívna rezonančná teória

Stabilita:

- ▶ V priebehu učenia sa **vytvárajú stabilné stavy**, ktoré zabezpečujú priamu odozvu na už známu vzorku, pričom sa vnútorne rozhoduje o tom, či sa pre prezentovanú vzorku vytvorí nová kategória, alebo či sa vykoná iba úprava kódu niektorej už existujúcej kategórie.

Adaptívna rezonančná teória

- ▶ Stephen Grossberg a Gail Carpenterová
- ▶ Vypracovaná metóda sa nazýva Adaptive Resonance Theory (**ART - teória adaptácie a rezonančnej odozvy**).
- ▶ Teória bola spracovaná do neurónovej siete, ktorá sa v reálnom čase samoorganizuje a vytvára stabilne rozpoznávacie kódy ako odozvu na ľubovoľné sekvencie vstupných vzoriek.

Adaptívna rezonančná teória

- ▶ Názov **ART** súvisí so spôsobom, akým v sieti prebieha učenie a hľadanie víťaza.
- ▶ Vstupná informácia osciluje vo forme signálov reprezentovaných aktiváciami neurónov medzi dvomi vrstvami neurónov až dokiaľ sa nedosiahne **rezonancia**. V tom momente nastáva učenie sa, čiže adaptácia váh.

Adaptívna rezonančná teória

Rezonancia môže nastať dvoma rôznymi spôsobmi:

- ▶ sieť už v minulosti spracovávala takú istú alebo veľmi podobnú vzorku – rezonancia nastáva okamžite;
- ▶ vstupná vzorka je odlišná od všetkých predošlých – spúšťa sa proces prehľadávania naučených kódov a porovnáva sa ich podobnosť s prezentovanou vzorkou, pričom je definovaná určitá prahová hodnota – parameter bdlosti, ktorá určuje minimálnu akceptovateľnú podobnosť víťaznej triedy.

Adaptívna rezonančná teória

- ▶ Ak tento prah nespĺňa žiadna z už známych tried, systém vytvorí novú triedu, identickú so vstupnou vzorkou. Takto sa zároveň dosahuje stabilita (sieť rezonuje v prípade známeho vstupu) aj plasticita (zachovanie schopnosti učiť sa nové neznáme vzorky).
- ▶ Základom ART sietí je **neurónová sieť ART 1**, ktorá je určená pre spracovanie binárnych vzoriek.
- ▶ Existujú zložitejšie modely typu ART sietí.

ART – motivácia a základné rysy

- ▶ Zachovať biologické chovanie sa neurónov, **ART siete majú učenie bez dozoru a samoorganizáciu**
- ▶ Proces samoorganizácie učenia bez dozoru vedie k vytvoreniu vzorov klastrov
- ▶ „Rezonancia“ sa odvoláva na tzv. rezonančný stav siete, v ktorom vzor klastra (vektor) dostatočne reprezentuje priebežný vstupný vektor


ART – motivácia a základné rysy

- ▶ ART siete sú navrhnuté tak, aby používateľ mohol riadiť stupeň podobnosti vzorov umiestnených do toho istého klastra
- ▶ Na riešenie dilemy S/P je navrhnutá dvojsmerná štruktúra a trikové operácie

Rozpoznávacia
vrstva




y_0 y_1 ... y_{M-2} y_{M-1}



Riadiaci signál 2
(logické signály)

Dopredné a
spätne váhy



Porovnávacia
vrstva



Riadiaci signál 1 x_0 x_1 ... x_{N-2} x_{N-1}

Idey ART modelu:

- ▶ Predpokladajme, že vstupné vzorky boli vhodne klasifikované do k klastrov (v zmysle súťažného učenia).
- ▶ Každý váhový vektor b_j je reprezentantom (priemerom) všetkých vzoriek v tomto klasi.
- ▶ Keď je na vstupe nový vstupný vektor x

1. Nájsť víťaza j^* medzi všetkými k reprezentantmi klastrov

2. Porovnať b_{j^*} s x

ak sú **dostatočne podobné** (x rezonuje s triedou j^*),

potom upraviť b_{j^*} na základe $|x - b_{j^*}|$


inak, nájsť/vytvoriť nového reprezentanta klastra a x

bude jej prvým členom.

Idey ART modelu

- ▶ Aby sme toto dosiahli, musíme mať:
 - ▶ mechanizmus pre testovanie a určovanie (ne)podobnosti medzi x and b_{j^*} .
 - ▶ metódu pre nájdenie/vytvorenie nového klastra.
 - ▶ Implementované všetky operácie pomocou jednotiek pre lokálne výpočty.
- ▶ Len základné idey sú tu uvedené
 - ▶ Zjednodušenie originálneho ART modelu
 - ▶ Niektoré z riadiacich mechanizmov sú realizované rôznymi špeciálnymi neurónmi – logické príkazy.

ART1 Architektúra



x : vstup (vstupné vektory)

y : výstup (triedy)

$b_{j,i}$: váhy zdola nahor, od x_i do y_j (reálne hodnoty)

$t_{i,j}$: váhy zhora nadol od y_j do x_i (binárne/bipolárne)

ρ : parameter pre porovnanie podobnosti ($0 < \rho < 1$)

Práca ART1

3 fázy sú použité pre každý vstupný vektor \mathbf{x}

Rozpoznávací fáza: určiť víťazný klaster pre \mathbf{x}

- ▶ Použitím váh zdola nahor \mathbf{b}
- ▶ Víťaz j^* s maximálnym $y_{j^*} = \mathbf{b}_{j^*} \odot \mathbf{x}$
- ▶ \mathbf{x} je predbežne zaradený do klastra j^*
- ▶ Víťaz môže byť veľmi ďaleko od \mathbf{x} (napríklad, $|\mathbf{t}_{j^*} - \mathbf{x}|$ je neakceptovateľne veľké)

Práca ART1

Porovnávací fáza:

- ▶ Vypočítať podobnosť použitím váh zhora nadol t :

vektor:

$$s^* = (s_1^*, \dots, s_n^*) \text{ kde } s_i^* = t_{l,j^*} \cdot x_l$$
$$s_i^* = \begin{cases} 1 & \text{ak oba } t_{l,j^*} \text{ a } x_l \text{ sú } 1 \\ 0 & \text{inak} \end{cases}$$

- ▶ Ak $(\#1 \text{ v } s) / (\#1 \text{ v } x) > \rho$, akceptovať klasifikáciu, upraviť b_{j^*} a t_{j^*}
- ▶ inak: odstrániť j^* z ďalších úvah, hľadať iných potenciálnych víťazov alebo vytvoriť nový klaster, v ktorom je x ako prvý vzor.

Úprava váh/adaptívna fáza

- ▶ Inicializovať váhy: (žiadny bias)

zdola nahor: $b_{j,l}(0) = 1/(n+1)$ zhora nadol: $t_{l,j}(0) = 1$

- ▶ Keď sa vyskytne rezonancia, vrchol j^* , upraviť b_{j^*} a t_{j^*}

$$b_{j^*,l}(\text{nové}) = \frac{s_l^*}{0.5 + \sum_{i=1}^n s_i^*} = \frac{t_{l,j^*}(\text{staré})x_l}{0.5 + \sum_{l=1}^n t_{l,j^*}(\text{staré})x_l}$$

$$t_{j^*,l}(\text{nové}) = s_l^* = t_{j^*,l}(\text{staré}) \cdot x_l$$

Úprava váh/adaptívna fáza

- ▶ Ak k vzorov je v klastri vrcholu j , tak

t_j = vzoru, ktorého 1's sú spoločné všetkým týmto k vzorom

$$t_j(\text{nové}) = t_j(0) \wedge x(1) \wedge x(2) \dots x(k) = x(1) \wedge x(2) \dots x(k)$$

$b_{j,l}(\text{nové}) \neq 0$, ak $s_l \neq 0$ len, ak $x_l(i) \neq 0$

b_j je normalizované t_j

Algorithm ART1:

Initialize each $t_{\ell,j}(0) = 1$, $b_{j,\ell}(0) = \frac{1}{n+1}$;

while the network has not stabilized, do

1. Let A contain all nodes;
2. For a randomly chosen input vector x , compute $y_j = b_j \cdot x$ for each $j \in A$.
3. repeat

(a) Let j^* be a node in A with largest y_j .

(b) Compute $s^* = (s_1^*, \dots, s_n^*)$ where $s_\ell^* = t_{\ell,j^*} x_\ell$;

(c) If $\frac{\sum_{\ell=1}^n s_\ell^*}{\sum_{\ell=1}^n x_\ell} \leq \rho$ then remove j^* from set A

else associate x with node j^* and update weights:

$$b_{j^*,\ell}(\text{new}) = \frac{t_{\ell,j^*}(\text{old}) x_\ell}{0.5 + \sum_{\ell=1}^n t_{\ell,j^*}(\text{old}) x_\ell}$$

$$t_{\ell,j^*}(\text{new}) = t_{\ell,j^*}(\text{old}) x_\ell$$

until A is empty or x is associated with some node;

4. If A is empty, create new node with weight vector x ;

Príklad

$$\rho = 0.7, \quad n = 7$$

Vstupné vzory

$$x(1) = (1, 1, 0, 0, 0, 0, 1) \quad x(2) = (0, 0, 1, 1, 1, 1, 0)$$

$$x(3) = (1, 0, 1, 1, 1, 1, 0) \quad x(4) = (0, 0, 0, 1, 1, 1, 0)$$

$$x(5) = (1, 1, 0, 1, 1, 1, 0)$$

$$\text{inicializácia : } t_{l,1}(0) = 1, \quad b_{1,l}(0) = 1/8$$

► Príklad - pokračovanie

Pre vstup $x(1)$ $y_1 = \frac{1}{8} \times 1 + \frac{1}{8} \times 1 + \frac{1}{8} \times 0 + \dots + \frac{1}{8} \times 0 + \frac{1}{8} \times 1 = \frac{3}{8}$

Vrchol 1 vyhráva $\frac{\sum_{\ell=1}^7 t_{\ell,1} x_{\ell}}{\sum_{\ell=1}^7 x_{\ell}} = \frac{3}{3} = 1 > 0.7$

$$b_{1,\ell}(1) = \begin{cases} \frac{1}{0.5+3} = \frac{1}{3.5} & \text{for } \ell = 1, 2, 7; \\ 0 & \text{otherwise.} \end{cases} \quad t_{\ell,1}(1) = t_{\ell,1}(0)x_{\ell}$$

$$T(1) = \begin{bmatrix} 1 & 1 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

$$B(1) = \begin{bmatrix} \frac{1}{3.5} & \frac{1}{3.5} & 0 & 0 & 0 & 0 & \frac{1}{3.5} \end{bmatrix}$$

Poznámky

1. Klasifikácia ako vyhľadávací proces
2. Žiadne dve triedy nemajú rovnaké ***b*** a ***t***
3. Vstupom, ktoré nepadnú do nejakého iného klastra, bude priradený nový klaster
4. Rôzne usporiadanie vstupných vzorov, môže viesť k rôznym klasifikáciám.

Poznámky

1. Zvýšenie ρ zvýši # naučených tried, a zníži priemernú veľkosť triedy.
2. Klasifikácia sa môže počas hľadania posúvať, pokým nebude dosiahnutá stabilita.
3. Existuje viacero modelov ART1 siete, ktoré sa líšia len málo.